

ダイナミックバイナリーニューラルネットの学習と安定化

| | |
|-----|---|
| 著者 | 佐藤 龍直 |
| 出版者 | 法政大学大学院理工学・工学研究科 |
| 雑誌名 | 法政大学大学院紀要. 理工学・工学研究科編 |
| 巻 | 58 |
| 発行年 | 2017-03-31 |
| URL | http://hdl.handle.net/10114/13533 |

ダイナミックバイナリニューラルネットの学習と安定化

LEARNING AND STABILIZATION OF DYNAMIC BINARY NEURAL NETWORKS

佐藤 龍直

Ryuji SATO

指導教員 斎藤利通

法政大学大学院理工学研究科電気電子工学専攻修士課程

A dynamic binary neural network is a simple two-layer network with a delayed feedback and is able to generate various binary periodic orbits. The network is characterized by the signum activation function, ternary connection parameters, and integer threshold parameters. The ternary connection brings benefits to network hardware and to computation costs in numerical analysis. The dynamics is simplified into a digital return map on a set of lattice points. We investigate the relation between sparsity of network connection and stability of a target periodic orbit. In order to stabilize a desired binary periodic orbit, we introduce some methods algorithm uses Each individual is evaluated by some feature quantities that characterize the stability of the periodic orbit. Applying the algorithm to a class of periodic orbits that are applicable to control signals of switching power converters, the usefulness of sparsification in stabilization of desired periodic orbit is confirmed.

Key Words : Dynamic binary neural networks, Stabilization, Feature quantities

1. まえがき

動的バイナリニューラルネット (DBNN)[1]-[5] は簡素な 2 層のネットワークに遅延フィードバックを適用させたものであり、それによって多彩な 2 値周期軌道を生成することができる。本ネットワークはシグナム活性化関数と 3 値の結合パラメータ、整数しきい値パラメータによって特徴づけられる。結合を 3 値にすることはネットワークハードウェアや数値解析の計算コストの面において有益である。本ダイナミクスは点の集合の力学系であるデジタルリターンマップに帰着させることができる。DBNN はパワーエレクトロニクス分野 [6] へ、また、同じデジタル力学系であるセル・オートマトンは信号処理 [7] への応用が研究されている。

はじめにスパース量の変化と周期軌道の安定性の関係について調査する。また結合パラメータを最多スパースとすることで、動的バイナリニューラルネットが安定な周期軌道が存在しないシフトレジスタのシステムと等価になるという問題についても調査する。

次に所望の周期軌道を安定化させるため、簡素な進化計算アルゴリズム [2] を導入する。本アルゴリズムは初期個体が 2 値結合パラメータである個体に 1 つずつ 0 を挿入した 3 値の結合パラメータを使用する。それぞれの個体は 2 つの周期軌道の安定性に関する特徴量によって更新される。0 の挿入は安定性の強化やハードウェアにおける消費電力の低減が期待される。あるクラスの周期軌道にアルゴリズムを適用することで、安定化の範囲を調査する。

また、簡素なクラスの 2 層ネットワークに関して、特徴量を計算することで本ネットワークが多彩な 2 値周期軌道を生成することができることを確認できる。3 層のネットワークを構成するための同じ周期軌道を生成することができる 2 層ネットワークを複数用意し、それらのネットワークを 2 つ

混ぜることで 3 層ネットワークにする方法 [8] を導入する。この方法で生成した 3 層ネットワークでは所望の周期軌道の安定性が強化される。数値実験を通して、混ぜ合わせ法の有用性を実証する。

2. 動的バイナリニューラルネット

2 層のネットワークに遅延フィードバックを適用することで、動的バイナリニューラルネット (DBNN) は図 1(a) のように構成される [1]-[5]。DBNN の動作は次式で記述される：

$$x_i^{t+1} = F \left(\sum_{j=1}^N w_{ij} x_j^t - T_i \right), \quad i = 1 \sim N \quad (1)$$

$$F(x) = \begin{cases} +1 & \text{if } x \geq 0 \\ -1 & \text{if } x < 0 \end{cases}, \quad T_i = 0$$

ここで $x^t \equiv (x_1^t, \dots, x_N^t)$ は離散時刻 t における 2 値状態ベクトルであり、 $x_i^t \in \{-1, +1\} \equiv B$ は i 番目の要素である。シグナム活性化関数は $+1$ または -1 を出力する関数である。シグナム活性化関数はバイナリニューラルネット (BNNs [1]-[3]) を含む様々な人工ニューラルネットに使われている。式 (1) を $x^{t+1} = F_D(x^t)$ と略記する。初期状態ベクトル x^1 が入力されると、DBNN は次の 2 値ベクトル $\{x^t\}$ を生成する。結合パラメータ w_{ij} は 3 値で、しきい値パラメータ T_i は整数値である：

$$w_{ij} \in \{-1, 0, +1\}, \quad T_i \in \{0, \pm 1, \pm 2, \pm 3, \dots\} \quad (2)$$

x は図 1 (b) に示すように整数なので、DBNN の動作は整数演算で計算することが可能で、数値解析において計算コストを抑えることができる [9]。前述したように、3 値の結合パラメータは [9] で提案されているデジタル回路によるハードウェア実装の際に有益である。 $w_{ij} = 0$ はハードウェアに

において回路の遮断に対応するため、0の要素は消費電力の低減が期待できる。

DBNNの動作を視覚化するために、デジタルリターンマップ (Dmap) を導入する。DBNNは N 次元2値ベクトル B^N の集合であり、 2^N 個の点の集合と同値である：

$$L_N \equiv \{c_1, \dots, c_{2^N}\}, c_i = \frac{i}{2^N} \equiv h(b_i), b_i \in B^N \quad (3)$$

ただし、 i は2進数コードである b_i を10進数に変換したものである。 $1/2^N \dots 2^N/2^N$ は B^N における 2^N 個の要素に対応する。式(3)によってDBNNの動作はDmap L_N 上に表現することができる。

$$\theta^{t+1} = f(\theta^t), \theta^t \in L_N, f(\theta) \equiv h \circ F_D \circ h^{-1}(\theta) \quad (4)$$

図2は $N = 4$ のDmapを描いているが、2進数は $L_4 = \{c_1, \dots, c_{2^4}\}$ を表現するために用いられる： $c_1 \equiv (-1, -1, -1, -1)$, $c_2 \equiv (-1, -1, -1, +1)$, \dots , $c_{2^4} \equiv (+1, +1, +1, +1)$ 。点の数は 2^N なので、 N が増加すると入力や出力をすべて直接記憶させることは困難になる。しかしDBNNにおいては、パラメータの数は $N^2 + N$ 個なので、DmapはDBNNの動作の視覚化に便利である。

点の数は有限なので、Dmapにおける定常状態は以下のように定義された周期的軌道でなければならない。

周期点の定義：ある点 $\theta_p \in L_D$ が、 $\theta_p = f^p(\theta_p)$, $\theta_p \neq f^l(\theta_p)$, $1 \leq l < p$ を満たすとき、 θ_p 周期 p の周期点 (PEP) とよぶ。ただし、 f^k は f の k 回合成写像である。特に周期1のPEPを不動点とよぶ。PEPの系列 $\{\theta_p, f(\theta_p), \dots, f^{p-1}(\theta_p)\}$ を周期 p の周期軌道 (BPO) とよぶ。図2において、Dmap上には周期3のBPOが存在し、それはDBNNにおける周期3のBPOに対応する：

$$c_2 \equiv (-1, -1, -1, +1) \rightarrow c_8 \equiv (-1, +1, +1, +1) \rightarrow c_{14} \equiv (+1, +1, -1, +1) \rightarrow c_2 \rightarrow \dots \quad (5)$$

周期 p の目的の2値周期軌道 (TBPO) を考える：

$$\begin{cases} z^1, z^2, \dots, z^p, z^{p+1}, \dots \\ \begin{cases} z^i = z^j & \text{for } |i - j| = np \\ z^i \neq z^j & \text{for } |i - j| \neq np \end{cases} \end{cases} \quad (6)$$

ただし n は正の整数である。このBPOを教師信号BPO (TBPO) とし、安定性強化の目的とする。便宜上、式(6)のTBPOを次の p 個の教師信号のペアとして考える：

$$(\xi^\tau, \eta^\tau) = (z^\tau, z^{\tau+1}), \tau \in \{1, \dots, p\} \quad (7)$$

ただし、 $\eta^p = z^{p+1} = z^1$ である。 ξ^τ と η^τ はDmap上のTPEPに対応する。パラメータ (w_{ij}, T_i) が以下を実現するとき、そのDBNNはTBPOを埋め込むことができる：

$$\eta^\tau = F_D(\xi^\tau), \tau \in \{1, \dots, p\} \quad (8)$$

以下を満たすとき、式(8)は保証される：

$$\begin{aligned} \sum_{j=1}^N w_{ij} \xi_j^\tau &\equiv r(i, \tau) \geq T_i & \text{for } i \text{ such that } \eta_i^\tau = +1 \\ \sum_{j=1}^N w_{ij} \xi_j^\tau &\equiv l(i, \tau) < T_i & \text{for } i \text{ such that } \eta_i^\tau = -1 \end{aligned} \quad (9)$$

したがって、次式で示す埋め込みのための十分条件を得る：




図1 (a) DBNNのネットワーク図。赤線と青線はそれぞれ $w_{ij} = +1$ と $w_{ij} = -1$ を示している。無結合は $w_{ij} = 0$ を表している。(b) シグナム活性化関数。




図2 Dmap。3周期軌道が存在する。

$$\begin{aligned} L(i) &< R(i) \quad \text{for all } i \\ L(i) &= \max_{\tau} l(i, \tau), \quad R(i) = \min_{\tau} r(i, \tau) \end{aligned} \quad (10)$$

E周期軌道の定義： $\theta_e \in L_D$ がPEPではなく写像を何回か施すことで、PEP θ_p ($F^q(\theta_e) = \theta_p$ ただし q は正の整数)に落ち込む点をE周期点 (EPP) とよぶ。EPPから出た軌道は、PEPあるいはそれに対応するBPOへ落ち込む。多くのEPPがBPOへ落ち込むとき、そのBPOは安定であるといえる。図2では、黒点がBPOへ落ち込むEPPに対応しており、そのBPOは安定である。

3. 特徴量

DBNNの動作を解析するために特徴量を導入する。SR, α , β 第1の特徴量は結合のスパース性に基づくものである。

$$SR = \frac{\text{The number of zero in } W}{N^2 - N}, 0 \leq SR \leq 1 \quad (11)$$

ただし、 W は結合行列を示す。SRが増加は結合が疎であることを表す。

第2の特徴量は教師信号へ落ち込むEPPの割合に基づくものである。

$$\alpha = \frac{\# \text{EPPs falling into a TBPO}}{2^N}, 0 \leq \alpha \leq 1 \quad (12)$$

特徴量 α が1に近いほど、教師信号は大域安定であることを示す。第3の特徴量は教師信号の一樣性に基づくものである。

$$\beta = \min_i \frac{M_i}{2^N/p}, i = 1 \sim p, 2/2^N \leq \beta \leq 1 \quad (13)$$

ただし、 M_i は i 番目のTPEPに落ち込む初期値の数である。特徴量 β が1に近いほど、教師信号は一樣安定であることを示す。

4. DBNN の学習および解析

ニューラルネットはパワーエレクトロニクス分野への応用が研究されている [6]。教師信号の例として、表 1 に示した周期 6 の BPO(TBPO) を用いる。この信号は簡素な DC/AC コンバータのスイッチング回路制御に応用可能である。

表 1 DC/AC コンバータに応用可能な TBPO

| | | | | | | |
|-------|----|----|----|----|----|----|
| z^1 | +1 | -1 | -1 | -1 | +1 | +1 |
| z^2 | +1 | +1 | -1 | -1 | -1 | +1 |
| z^3 | +1 | +1 | +1 | -1 | -1 | -1 |
| z^4 | -1 | +1 | +1 | +1 | -1 | -1 |
| z^5 | -1 | -1 | +1 | +1 | +1 | -1 |
| z^6 | -1 | -1 | -1 | +1 | +1 | +1 |

まず、DBNN の安定性とスパース化の関係を考えるために、特徴量 SR と α の関係性を調べる。しかし、DBNN のネットワークを全探索することは困難であるため、相関学習によって決定した TBPO の埋め込みが保証されている結合行列を 1 つ用意し、そこから 0 の挿入数を指定し、スパース化を複数回施すことによって統計的なデータを得ることとする。このとき、各入力が最低 1 つの出力に結合するようにスパース化を施すと、SR = 30 の DBNN はシフトレジスタに対応する。

各 SR(0 ~ 30) においてランダムスパースを 30 回適用し、平均を求めた。図 3 はランダムスパースによる統計データである。相関学習後の DBNN では $\alpha = 36/58$ であったが、SR = 3 ~ 26 で $\alpha_{max} = 1$ となった。また、SR = 1 ~ 19 で α_{ave} は高い値 ($\alpha \geq 50/58$) を記録した。

次に、TBPO が埋め込み可能である 2 層 DBNN を複数 (547) 個用意する。このとき、特徴量 α を評価関数として使用し、各 DBNN の大域安定性を評価する。図 4 に 547 個の 2 層 DBNN の α_2 ヒストグラムである。

547 個の 2 層 DBNN から 2 つの DBNN を組み合わせ、3 層 DBNN にする混ぜ合わせ法 [8] を使用することで、TBPO の大域安定化を図る。ただし、混ぜ合わせ法で使用する 2 層 DBNN の結合行列はすべて 2 値結合 ($w_{ij} = \{+1, -1\}$) である。図 5 に 547 個の最良 3 層 DBNN の α_3 ヒストグラムである。




図 3 統計データ。(a) 相関学習 DBNN。(b) シフトレジスタ DBNN。

図 6 は TBPO における最良 3 層 DBNN を示している。1 層目に使用した 2 層 DBNN は相関学習によって得られた結合行列を使用している ($\alpha_2 = 36/58$)。この 2 層 DBNN に対し、混ぜ合わせ法を適用した。偽記憶が多層化によって消去され、大域安定性が強化された ($\alpha_3 = 54/58$)。また、図 7 は $\alpha_2 - \alpha_3$ 平面上の散布図であり、X は図 6 の結果を示す点である。

相関学習では TBPO を埋め込むことができるが、一様安定化の観点からみると、最適値からは遠い結果となる：図 8(a),(c) はそれぞれ相関学習後の DBNN と Dmap を示している。 $\alpha = 36/58, \beta = 7/11$ となり、一様安定性はあまり高くないことがわかる。そこで、特徴量 α, β を評価関数として使用し、DBNN の個体を進化させる。このために、貪欲法に基づくスパース化アルゴリズム (GSS)[2] を導入する。

図 8(b),(d) はそれぞれ GSS 適用後のスパース化した DBNN と Dmap を示している。2 つの特徴量はそれぞれ $\alpha = 58/58, \beta = 10/11$ となった。また、図 9 は GSS の進化過程である。GSS では α の値を最適値に、 β の値も大きく改善することができた。

以上のことから DBNN の多層化は大域安定性の強化に、DBNN のスパース化は一様安定性、大域安定性の両方を強化することに有用であることが考えられる。




図 4 TBPO における 1 層目 2 層 DBNN の α_2 ヒストグラム。




図 5 TBPO における最良 3 層 DBNN の α_3 ヒストグラム。




図 6 TBPO における最良 3 層 DBNN の $\text{Dmap}(\alpha_3 = 54/58)$.




図 7 TBPO における $\alpha_2 - \alpha_3$ 平面上の散布図 .

5. むすび

本論文では動的バイナリニューラルネット (DBNN) の学習・安定化をするために特徴量を導入した。DBNN のダイナミクスはカオスの発生しない簡素なものであるが, DBNN は様々な現象を呈する。定常状態・過渡現象に関する特徴量を導入し, 現象の解析もおこなった。これらの特徴量は DBNN の学習や解析をおこなう上での新手法の第一歩である。今後の課題として, 多層 DBNN の詳細な解析, 動作のパラメータに対する依存性, 特徴量平面上的での DBNN の学習, DBNN の工学的応用などがあげられる。

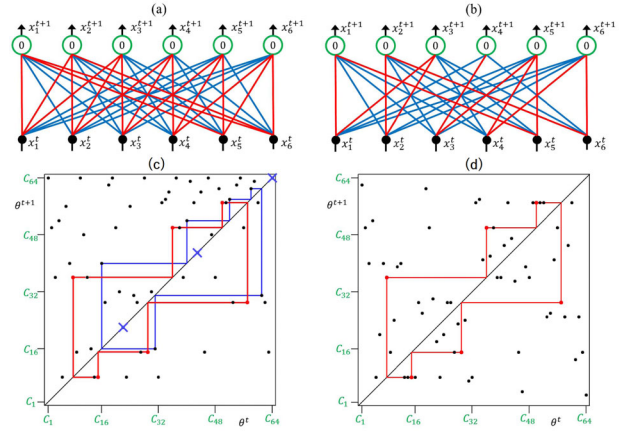


図 8 DBNN と Dmap . (a) 相関学習後の DBNN . (b) GSS 適用後の DBNN . (c) 相関学習後の Dmap . (d) GSS 適用後の DBNN .




図 9 進化過程 . (a) α, β vs t . (b) $\alpha - \beta$ 平面上的での軌跡 . A: 相関学習後 . B: GSS 適用後 . X: 理想値 .

参考文献

- 1) Kouzuki, R. and Saito, T.: Learning of simple dynamic binary neural networks, IEICE Trans. Fundamentals, E96-A, 8, 1775-1782 (2013)
- 2) Sato, R. and Saito, T.: Simple feature quantities for learning of dynamic binary neural networks, (S. Arik et al. (Eds.): ICONIP 2015, Part I), LNCS 9489, 226-233 (2015)
- 3) Sato, R., Makita, K., and Saito, T.: Analysis of various periodic orbits in simple dynamic binary neural networks, Proc. IJCNN, 2031-2038 (2016)
- 4) Nowara, K. and Saito, T.: Guaranteed storing of limit cycles into a discrete-time asynchronous neural network, Trans. IEICE, E75-A, 11 1579-1582 (1992)
- 5) Jiang, X., Gripon, V., Berrou, C., and Rabbat, M.: Storing sequences in binary tournament-based neural networks, IEEE Trans. Neural Netw., 27, 5, 913-925 (2016)
- 6) Vithayathil, J.: Power electronics, McGraw-Hill (1992)
- 7) L. O. Chua, A nonlinear dynamics perspective of Wolfram's new kind of science, I, II. World Scientific, 2005.
- 8) Sato, R., Kazuma, M., and Saito, T.: Analysis of Various Periodic Orbits in Simple Dynamic Binary Neural Networks, Proc. IJCNN2016, 2031-2038 (2016)
- 9) Courbariaux, M., Bengio, Y., and David, J.-P.: Binary connect: training deep neural networks with binary weights during propagations, Advances in Neural Information Processing Systems 28, 3105-3113 (2015)